

基于深度置信网络的低压台区理论线损计算方法

马丽叶¹, 刘建恒¹, 卢志刚¹, 王海云², 袁清芳², 杨莉萍²

(1. 燕山大学 电力电子节能与传动控制河北省重点实验室, 河北 秦皇岛 066004;
2. 国网北京市电力公司电力科学研究院, 北京 100075)

摘要:针对因线路分布复杂、终端数目庞大等带来的低压台区理论线损计算困难的问题,提出一种基于深度置信网络(DBN)的低压台区理论线损计算新方法。在训练过程中,先利用贪婪算法对DBN模型中的神经网络层进行逐层无监督的预训练,再对该模型进行有监督的全局微调。为了提高计算精度,采用自适应时刻估计(Adam)优化器。以某地区实测2140个台区数据为样本进行仿真计算,结果表明,相较于浅层神经网络,DBN线损计算模型具有更好的泛化能力以及准确性和快速性,且Adam优化器在线损计算中相较于均方根反向传播(RMSProp)和随机梯度下降(SGD)算法具有优越性。

关键词:低压台区;理论线损;深度置信网络;贪婪逐层训练法;自适应时刻估计

中图分类号:TM 74

文献标志码:A

DOI:10.16081/j.epae.202007036

0 引言

随着国家经济快速发展、供电量不断增长和配电网规模日益扩大,低压台区线损计算困难问题逐渐凸显。低压台区线损是电力系统经济运行的一个重要技术指标,也是电力公司的重点管理内容之一。理论线损计算不仅为制定降损方案、线损考核提供了理论依据,还为配电网规划提供了有效的指导建议,因此研究台区理论线损情况对提高配电网的经济运行有十分重要的意义。但是低压台区线路复杂、终端数目庞大,这些都给低压台区理论线损建模带来了困难,使理论线损值计算不准确。

随着以神经网络、深度学习、大数据为代表的新一代人工智能技术的快速发展,基于深度学习和数据驱动^[1-2]解决电力系统所面临的困难逐渐成为研究的热点。深度学习是将数据进行组织形成信息,再对相关信息进行整合和提炼,通过对数据进行训练和拟合形成自动化的决策模型,其通常采用离线训练、在线更新的方式,广泛应用于负荷预测^[3-4]、变压器故障诊断^[5]、电网可靠性评估^[6]、配电网状态估计^[7]、风电功率概率预测^[8]等方面。近年来,随着国家智能电网的不断建设,低压台区自动化水平逐年提高,数据采集系统日趋完善,为低压台区线损计算提供了大量数据,神经网络、深度学习等算法逐渐被引进到理论线损计算中。

目前,有学者提出新的计算方法,但均存在一定的问题。文献[9]利用改进的核心向量机对配电网进行计算,但是难以对数量庞大的台区进行计算,当

样本数据增加时,该方法会耗费大量机器内存和运行时间。文献[10]提出使用回归分析方法来进行线损计算,但是回归方程往往难以确定。文献[11-14]均提出对配电网进行分类,再对相似的部分利用BP神经网络算法进行配电网线损计算,但是传统的BP神经网络存在容易陷入局部最小的问题,而且收敛速度慢。文献[15]提出一种灰色关联法和遗传改进的神经网络相结合的线损计算模型用于10 kV配电网线损计算。文献[16]提出一种基于改进K-Means聚类算法和Levenberg-Marquardt算法优化的BP神经网络模型计算低压台区线损率的方法,但是文中仅使用训练集进行学习,并未将训练好的模型用于未知台区的预测,因此无法得到对未知台区的计算效果。文献[17-18]将遗传算法和BP神经网络相结合,克服了BP神经网络陷入局部最小的问题,在一定程度上提高了线损计算精度,但是文中研究对象为配电网。在这些神经网络线损计算中都是浅层结构,难以提取线损计算中的复杂非线性关系,因此很难满足计算精度的要求。相比于浅层神经网络,深度学习^[11-20]可以高效提取数据中的非线性关系,并且收敛性好。深度置信网络DBN(Deep Belief Network)由于具有特征提取能力强、模型简单、收敛性好等优点,被广泛应用在各领域中^[21-24]。

针对上述情况,本文提出一种基于DBN的台区理论线损率计算方法,利用其离线训练-在线计算模式。离线训练过程中,首先根据台区实际情况筛选出用来刻画台区网架结构和运行状态的电气特征值,将其作为DBN线损计算模型的输入自变量;然后建立基于DBN的深度学习理论线损率计算模型,并采用预训练和反向微调2个阶段训练网络参数,为了得到更好的优化效果,采用自适应时刻估计Adam(Adaptive moment estimation)优化器优化的反

收稿日期:2020-01-06;修回日期:2020-06-19

基金项目:国家自然科学基金资助项目(61873225)

Project supported by the National Natural Science Foundation of China(61873225)

向微调对 DBN 进行全局调整,训练完成后保存模型参数,获取离线训练的模型。在线计算过程中,将保存的模型用于理论线损计算进行验证。

1 台区理论线损特征指标的建立

低压台区网架结构复杂,运行情况多样,影响线损的因素有多种,例如线路长度、供电半径、线路型号、变压器容量、供电量、用户负荷等。考虑这些数据指标对线损影响的大小、获取的难易程度,选取线路长度、用户负荷和线路型号作为低压台区的特征指标,即线损模型的输入。

(1) 线路长度。

线路长度是影响线损的一个重要指标。线路长度越长,线路的电阻值越大,从而线损就越大。本文采用低压台区主干线长度和支路线路长度,其长度不同。

(2) 用户负荷。

用户负荷直接影响线损,用户负荷越大,线损也就越大。本文采用每个用户一天的用电量,台区总负荷约为 1000~5000 kW·h。

(3) 线路型号。

不同线路型号电阻值差别很大。通常台区主干线的线径大,分支线路的线径小,线路型号主要有 LJ-150 和 LJ-120 这 2 种,本文采用主干线线路型号和支路线路型号获取其对应的阻值。

为了减小数值和量纲问题对计算的影响,需要对原始数据进行标准化处理,本文采用 Z-Score 标准化方法。设输入变量数量为 T ,总体样本数量为 H ,标准化方法如下:

$$X_{ij} = \frac{x_{ij} - \bar{x}_j}{s_{ij}} \quad (1)$$

$$\bar{x}_j = \frac{1}{H} \sum_{i=1}^H x_{ij} \quad (2)$$

$$s_{ij} = \sqrt{\frac{1}{H-1} \sum_{i=1}^H (x_{ij} - \bar{x}_j)^2} \quad (3)$$

其中, x_{ij} ($i=1, 2, \dots, H; j=1, 2, \dots, T$) 为第 i 个样本的第 j 个特征参数; X_{ij} 为 x_{ij} 标准化处理后的值; \bar{x}_j 为 x_{ij} 的平均值; s_{ij} 为 x_{ij} 的标准差。

对于低压台区理论线损计算问题,样本特征值即为模型的输入,将特征值数据集 X 和输出 Y 分别表示为:

$$X = \{L_{11}, \dots, L_{1l_1}, P_{11}, \dots, P_{1p_1}, O_{11}, \dots, O_{1l_1}, \\ L_{21}, \dots, L_{2l_2}, P_{21}, \dots, P_{2p_2}, O_{21}, \dots, O_{2l_2}, \\ \vdots \\ L_{N1}, \dots, L_{Nl_m}, P_{N1}, \dots, P_{Np_m}, O_{N1}, \dots, O_{Nl_m}\} \quad (4)$$

$$Y = \{\Delta P_1, \Delta P_2, \dots, \Delta P_N\} \quad (5)$$

其中, ΔP_i ($i=1, 2, \dots, N$) 为台区 i 的线损值, N 为台

区数; L_{11} 、 O_{11} 分别为台区 1 内第 1 条线路长度和单位电阻值, P_{11} 为台区 1 内第 1 个用户全天用电量, l_1 为台区 1 内线路数, p_1 为台区 1 内用户数, 其他类似。 X 中每一行构成一个台区的特征值。式(6)为具体的一个放射型台区数据(未进行标准化处理的原始数据)。

$$X_1 = \{0.1, \dots, 0.34, 1.298, \dots, 0.089, 0.24, \dots, 0.19\} \quad (6)$$

式中 0.1—0.34 为线路长度,单位为 km; 1.298—0.089 为用户负荷,单位为 MW·h; 0.24—0.19 为线路型号所对应的电阻值,单位为 Ω / km 。

2 DBN 理论线损计算模型

本节首先构建基于受限玻尔兹曼机 RBM (Restricted Boltzmann Machine) 堆叠而成的 DBN 线损计算模型,通过 DBN 强大的数据挖掘能力学习理论线损数据特征;其次,采用基于 Adam 优化的反向微调对模型进行训练,有效提高 DBN 模型的训练精度和收敛速度。DBN 线损计算框图如图 1 所示。



图 1 DBN 线损计算框图

Fig.1 Block diagram of line loss calculation based on DBN

2.1 RBM 模型

DBN 线损计算模型由多个 RBM 堆叠而成,而 RBM 是一个简单的由可见层和隐藏层构成的 2 层神经网络,可见层和隐藏层之间的神经元全连接,各层内的神经元未连接。RBM 结构如图 2 所示。

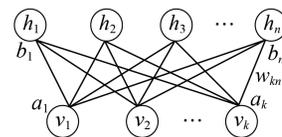


图 2 RBM 结构图

Fig.2 Structural diagram of RBM

在图 2 中,上层神经元构成隐藏层,共有 n 个神经元,用 $\mathbf{h} = (h_j) \in \mathbf{R}^n$ 表示隐藏层神经元的状态;下层神经元构成可见层,共有 k 个神经元,用 $\mathbf{v} = (v_i) \in \mathbf{R}^k$ 表示可见层神经元的状态。 $\mathbf{w} = (w_{ij}) \in \mathbf{R}^{k \times n}$ 为神经元之间的连接权重, $\mathbf{b} = (b_j) \in \mathbf{R}^n$ 为隐藏层的偏置, $\mathbf{a} = (a_i) \in \mathbf{R}^k$ 为可见层的偏置。

RBM 是一个基于能量的模型,若要对 RBM 模型进行训练,首先需定义一个能量函数。对于任意一组给定的状态 (\mathbf{v}, \mathbf{h}) ,可以定义如下能量函数:

$$E(\mathbf{v}, \mathbf{h} | \theta) = - \sum_{i=1}^k \sum_{j=1}^n w_{ij} v_i h_j - \sum_{i=1}^k a_i v_i - \sum_{j=1}^n b_j h_j \quad (7)$$

基于式(7),任意一组 (\mathbf{v}, \mathbf{h}) 的联合概率分布(也称为似然函数)为:

$$P(\mathbf{v}, \mathbf{h}) = \frac{1}{Z(\theta)} e^{-E(\mathbf{v}, \mathbf{h}|\theta)} \quad (8)$$

其中, $\theta = \{\mathbf{w}, \mathbf{a}, \mathbf{b}\}$ 为参数; $Z(\theta) = \sum_{\mathbf{v}, \mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h}|\theta)}$ 为归一化因子。

每层神经元均相互独立,因此可以通过可见层神经元状态计算隐藏层神经元状态。隐藏层第 j 个神经元激活概率为:

$$P(h_j = 1 | \mathbf{v}, \theta) = f\left(b_j + \sum_{i=1}^k v_i w_{ij}\right) \quad (9)$$

由于RBM模型是对称结构,因此当给定隐藏层的状态变量时,就可以得到可见层状态变量。可见层第 i 个神经元概率为:

$$P(v_i = 1 | \mathbf{h}, \theta) = f\left(a_i + \sum_{j=1}^n h_j w_{ij}\right) \quad (10)$$

其中, $f(x)$ 为激活函数,本文中采用线性整流ReLU(Rectified Linear Unit)函数,其表达式如式(11)所示。

$$f(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases} \quad (11)$$

给定线损样本数据 X ,通过最大化对数似然函数 $L(\theta)$ 学习训练得到模型的最优参数:

$$\theta^* = \operatorname{argmax}_{\theta} L(\theta) = \operatorname{argmax}_{\theta} \ln P(\mathbf{v}^k | \theta) \quad (12)$$

其中, $\operatorname{argmax}_{\theta} L(\theta)$ 表示取得 $L(\theta)$ 最大值所对应的变量点 θ 。

在RBM的训练中,重构后的期望很难直接计算得到,通常使用吉布斯采样取近似值,采用Hinton提出的快速计算方法,对比散度CD(Contrastive Divergence)算法^[25]近似求解 $P(\mathbf{v}^k | \theta)$,可得到各参数的更新公式如式(13)所示。

$$\begin{cases} w_{ij} = \partial w_{ij} + \eta(E_{\text{data}}(v_i h_j) - E_{\text{recon}}(v_i h_j)) \\ a_i = \partial a_i + \eta(E_{\text{data}}(v_i) - E_{\text{recon}}(v_i)) \\ b_j = \partial b_j + \eta(E_{\text{data}}(h_j) - E_{\text{recon}}(h_j)) \end{cases} \quad (13)$$

其中, E_{data} 为可见层初始化数据分布的期望; E_{recon} 为隐藏层重构后模型定义的期望; ∂ 为动量; η 为学习率。

2.2 DBN模型

DBN模型由多个RBM和1个BP神经网络输出层堆叠而成,拥有强大的自主学习和非线性拟合能力,其结构如图3所示。图中,顶层输出层作为回归,输出理论线损计算值,它通过前向学习与梯度下降的反向微调达到最优的模型训练。第1层神经元和第2层神经元形成第1个RBM,依此类推,直至第 n 层神经元,因此该DBN模型共有 $M-1$ 个RBM和1

个BP输出层。低压台区线损特征指标作为DBN模型的输入数据,经过DBN模型的无监督的预训练和有监督的反向微调过程不断提取线损输入数据的特征,拟合得到输出层的线损值。至此,基于DBN低压台区线损计算模型搭建完成。

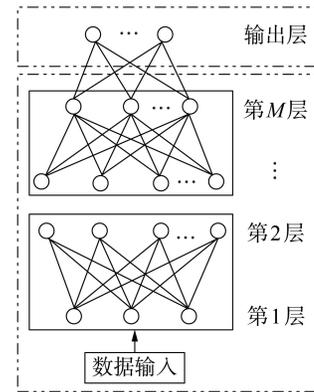


图3 理论线损计算DBN结构

Fig.3 Structure of theoretical line loss calculation based on DBN

2.3 DBN线损计算模型训练方法

DBN线损计算模型训练过程包括无监督的预训练和有监督的反向微调2个过程。

无监督的预训练是一个从底部神经层向顶部神经层学习的过程,它利用RBM的无监督贪婪训练机制进行逐层训练,通过输入线损特征值得到每个RBM的参数 θ ,实现将低层的数据特征逐层训练成高层特征,最后将其送入最顶层的输出层,为达到全局最优做准备。预训练的目的就是给参数 θ 提供一个优秀的初值,避免出现梯度下降算法在深层神经网络中梯度消失的问题。

有监督的反向微调是一个从上到下的反过程,首先求解出输出层结果与真实线损标签之间的误差,然后利用梯度下降算法,根据误差从顶层逐层向下调整模型内部系数 $\theta = \{\mathbf{w}, \mathbf{a}, \mathbf{b}\}$,从而达到降低误差的目的。预训练的目的在于找到模型最优解的大概范围,而反向微调是为了缩小这个范围并找到最优解。通过全局的微调过程,最终确定DBN模型的内部最优参数。正是DBN模型这2个阶段的训练提高了理论线损计算准确率。

在DBN模型结构训练中,由于随机梯度下降SGD(Stochastic Gradient Descent)算法在监督过程中样本是随机的,得到的损失函数并不一定是朝着全局最优的方向,因此SGD算法更新频率较高,会使损失函数振荡严重,容易造成局部收敛。图4为Adam与SGD算法的效果对比,将图中的实心圆看成最优解,Adam算法到达最优解的波动幅度要小于SGD算法。为了进一步加快收敛速度,均方根反向传播RMSProp(Root Mean Square Prop)优化算法

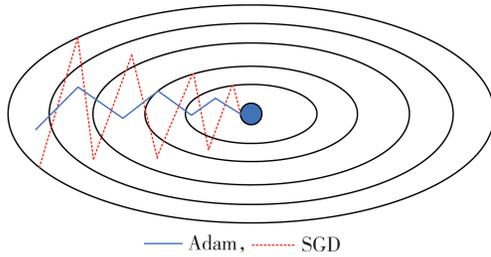


图4 Adam与SGD算法效果对比

Fig.4 Effect comparison between Adam and SGD algorithms

使用微分平均加权平均数,并且其学习率是自适应的。在深度学习最后的有监督反向微调过程中采用Adam算法进行优化。Adam是一种非常有效的自适应学习率梯度下降算法之一,其可以消除梯度下降中的摆动以及提高收敛速度。该算法不仅保留了平方梯度指数衰减平均值,还保留了梯度的指数衰减平均值,因此,其优化解决了损失函数在更新过程中摆动过大的问题,加快了函数的收敛速度。Adam算法对权重的梯度使用微分平方加权平均数,假设在 t 次迭代中,更新公式如下:

$$m_w^{t+1} = \beta_1 m_w^t + (1 - \beta_1) dw \quad (14)$$

$$v_w^{t+1} = \beta_2 v_w^t + (1 - \beta_2) dw^2 \quad (15)$$

$$\hat{m}_w = \frac{m_w^{t+1}}{1 - \beta_1^{t+1}} \quad (16)$$

$$\hat{v}_w = \frac{v_w^{t+1}}{1 - \beta_2^{t+1}} \quad (17)$$

$$w^{t+1} = w^t - \alpha \frac{\hat{m}_w}{\sqrt{\hat{v}_w} + \varepsilon} \quad (18)$$

其中, m_w^t 为一阶矩估计; v_w^t 为二阶矩估计; β_1 为常数,一般取为0.9; β_2 为常数,一般取为0.999; \hat{m}_w 为修正的一阶矩阵偏差; \hat{v}_w 为二阶矩阵偏差; α 为学习率; ε 为平滑度,为防止分母为0,一般取值为 10^{-8} 。

上述即为DBN的训练过程,利用训练好的DBN线损计算模型可以挖掘低压台区特征值与线损值之间的非线性关系。通过输入台区特征指标体系可以映射出理论线损值。

3 线损计算流程

DBN低压台区理论线损计算具体包括以下6个步骤。

(1)低压台区理论线损计算样本数据的获取。以某地区2140个低压台区理论线损计算结果作为本文数据集样本,并对样本数据进行预处理。

(2)DBN线损计算模型的初始化。包括隐藏层和输出层激活函数的选择,损失函数的选择以及隐藏层数、每层的神经元个数、学习率、动量、训练批次等超参数的确定。

(3)DBN线损计算模型的预训练。以样本特征指标体系数据作为输入,从DBN结构底层向顶层进行逐层训练,结合式(7)和式(8)确定每层的神经元状态。

(4)DBN线损计算模型的反向微调。将带有标签的样本数据集输入预训练完成的DBN中,以理论线损值作为输出。采用均方根损失函数,并使用Adam优化算法代替SGD算法,从而得到最优化参数 θ 。当满足预设定的精度或者到达预设定的迭代次数后,停止训练。此时DBN线损计算模型训练完成,保存模型参数。

(5)未知低压台区理论线损的测试计算。使用训练完成的DBN模型对未知低压台区线损进行计算,分析计算结果。

(6)扩展低压台区理论线损数据集,实时更新试验数据库,以提高训练精度。

4 算例验证及分析

本文以某地区2140个台区理论线损数据作为样本,选择其中1906个样本作为训练集,其余样本为验证集。从验证集中选取20个样本作为测试集1,其余样本为测试集2。本文进行线损计算的实验平台如表1所示。

表1 实验平台

Table 1 Experiment platform

	组成	版本或参数
硬件	处理器CPU	i5-4200M×4
	CPU频率	2.50 GHz
	内存RAM	4.00 GB
软件	Python	Anaconda5.2
	操作系统	Win10
	深度学习架构	Tensorflow1.12.0

4.1 3种优化算法在理论线损计算中的效果

本节以收敛精度以及收敛速度分析Adam、RMSProp、SGD算法对训练结果的影响。选择训练集和测试集1作为本节实验数据,DBN为训练框架,学习率为 10^{-3} ,动量为0.02,隐藏层数为4层,训练批次为600,最大迭代次数为10000次。

在收敛速度方面,通过比较3种反向微调优化算法达到0.01、0.001和0.0001这3个训练目标误差时所消耗的时间为标准。为了减小误差,以3种算法各进行20次仿真取平均值。表2为3种算法的平均训练时间对比。由表中可知:训练目标误差为0.01时,3种算法都可以收敛,Adam算法所需要的时间最短;训练目标误差为0.001时,SGD算法无法收敛,RMSProp算法收敛需26.379 s,而Adam算法收敛仅需14.259 s;训练目标误差为0.0001时,虽然RMSProp算法可以收敛到误差值,但消耗的时间约

为 Adam 算法的 2.7 倍。因此,使用 Adam 优化算法可以大幅缩短 DBN 线损计算训练中所需的时间。

表 2 Adam、RMSProp、SGD 算法平均训练时间对比

Table 2 Comparison of average training time among Adam, RMSProp and SGD algorithms

算法	平均训练时间 / s		
	误差为 0.01	误差为 0.001	误差为 0.0001
SGD	34.547	—	—
RMSProp	17.005	26.379	73.002
Adam	11.269	14.259	26.972

在精度方面,为了排除偶然性,采用 3 种算法各仿真 20 次,比较在迭代 10 000 次的条件下训练得到的最小误差值。SGD、RMSProp、Adam 算法得到的最小平均误差分别为 9.64×10^{-3} 、 5.614×10^{-5} 、 2.585×10^{-6} , Adam 算法的最小平均误差比 RMSProp 算法小一个数量级。因此,在 DBN 线损计算中所选择的 Adam 优化器能够满足训练误差,提供更准确的线损计算值。图 5 为 Adam 与 RMSProp 算法的最小误差值对比。由于 SGD 算法的最小误差值相较于 Adam 太大,因此未在图中显示。根据上述实验结果,本文选择 Adam 优化算法。

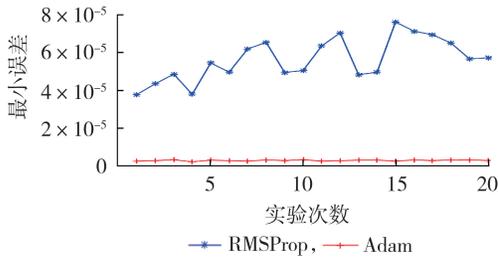


图 5 Adam 与 RMSProp 算法的最小误差值对比

Fig.5 Comparison of minimum error between Adam and RMSProp algorithms

4.2 DBN 模型的计算精度和收敛速度分析

为验证 DBN 线损计算的优越性,对 DBN 与标准 BPNN 线损计算进行对比。DBN 的隐藏层数设定为 4 层,最后一层为输出层,隐藏层的激活函数和输出层的激活函数均为 ReLU 函数,学习率为 10^{-3} ,动量为 0.01,最大迭代次数为 10 000 次,精度为 10^{-4} ,训练批次为 600,反向微调的训练方法为 Adam 优化算法;标准 BPNN 模型为浅层结构,因此设定隐藏层为单层,学习率为 0.05,动量为 0.01,其他参数均与 DBN 模型相同。计算结果如表 3 所示。

在计算速度方面,以计算测试集 1 中 20 个台区和测试集 2 中 214 个台区所消耗的时间为标准。DBN 与传统方法和标准 BPNN 的计算时间对比如表 4 所示。由表可见,传统方法计算测试集 1 线损的时间为 11.2 s,是 3 种算法中耗时最长的;DBN 模型计算线损的时间为 0.5 s;标准 BPNN 耗时 0.6 s,与 DBN 模型速度相当,但是其精度远不如 DBN 模型,如表 3 所

表 3 DBN 与标准 BPNN 的线损计算精度对比

Table 3 Comparison of line loss calculation accuracy between DBN and standard BPNN

理论线损值 / (kW·h)	DBN		BPNN	
	计算值 / (kW·h)	相对误差 / %	计算值 / (kW·h)	相对误差 / %
102.9	101.6	1.337	92.4	10.284
49.6	52.2	5.288	41.2	16.935
78.7	78.4	0.356	70.3	10.652
54.1	54.4	0.472	53.8	0.508
101.8	95.0	6.619	107.6	5.683
21.0	21.1	0.624	29.3	39.549
70.8	69.8	1.315	66.8	5.681
27.5	27.7	0.943	28.4	3.491
71.3	70.1	1.611	58.3	18.168
107.4	105.7	1.613	109.1	1.609
240.5	232.3	3.417	256.1	6.498
41.5	42.9	3.457	42.2	1.697
123.8	120.1	2.999	117.6	4.986
53.5	53.7	0.287	49.3	8.024
66.6	66.7	0.205	61.2	8.119
38.3	40.2	4.853	44.3	15.558
19.1	20.2	5.725	21.8	13.826
56.1	57.5	2.487	52.8	5.842
72.7	73.0	0.324	74.2	2.057
40.0	39.5	1.371	35.8	10.621

示。当线损数据增加到 214 个时,传统方法消耗的时间增加到 117 s,而 DBN 消耗的时间仅仅增加了 0.1 s,远小于传统方法所消耗的时间。因此,随着低压台区数量不断增加,传统方法计算效率大幅降低,而本文所提出的 DBN 线损计算可以满足计算速度的要求。

表 4 3 种方法线损计算时间对比

Table 4 Comparison of line loss calculation time among three methods

方法	计算时间 / s	
	测试集 1	测试集 2
传统方法	11.2	117.0
标准 BPNN	0.6	0.9
DBN	0.5	0.6

4.3 多数据验证

根据国家电网低压台区理论线损计算规定,低压台区理论线损需取该地区所有低压台区总数的 1% 进行计算,因此台区计算数据较大。为了进一步验证 DBN 模型应用于大规模低压台区理论线损计算的有效性,选择测试集 2 作为本节实验数据。DBN 的隐藏层数设定为 4 层,最后一层为输出层,隐藏层和输出层的激活函数均为 ReLU 函数,学习率为 2×10^{-3} ,动量为 10^{-3} ,最大迭代次数为 10 000 次,精度为 10^{-5} ,训练批次为 600,反向微调的训练方法为 Adam 优化算法;BPNN 为单隐层结构,学习率为 0.01,动量为 5×10^{-3} ,其他参数与 DBN 相同。计算结果如表 5 所示。

表 5 DBN 模型与 BPNN 模型大量测试集结果比较
Table 5 Results comparison of large numbers of test sets between DBN and BPNN models

相对误差 / %	DBN		BPNN	
	台区数量	占计算台区百分比 / %	台区数量	占计算台区百分比 / %
[0, 1]	157	73.36	17	7.94
(1, 5]	46	21.51	137	64.02
(5, 10]	7	3.27	44	20.56
(10, 20]	2	0.93	11	5.14
(20, 30]	2	0.93	5	2.34

由表 5 可见,相较于 BPNN 模型,DBN 模型的计算精度得到了很大提高,并且相对误差在 1% 以内时,DBN 模型的计算优势更加明显。

5 结论

本文针对低压台区理论线损计算问题,提出一种 DBN 的线损计算方案。利用 Tensorflow 框架构建 DBN 模型,并用 Adam 优化算法作为 DBN 训练时的梯度优化算法。以某地区实测 2 140 个理论线损数据进行仿真研究,以不同的测试集验证了所提方法的准确性,得到了以下结论。

(1) DBN 模型对低压台区理论线损计算有更好的训练效果。通过对比 DBN 线损计算模型和 BPNN 模型可以发现,DBN 线损计算模型的计算精度更高,收敛速度更快,而且其计算结果更接近理论线损值;配合 Adam 算法对模型的梯度下降进行优化,不仅增加了模型的适用性,而且提高了 DBN 理论线损计算模型精确度。

(2) 在计算速度方面,DBN 的计算速度要远快于传统方法,并且优于标准 BPNN 方法,在进行大规模低压台区线损计算时,可以大幅提高计算效率。

参考文献:

[1] 全营,钟斌,童水光. 基于机制模型与数据驱动的超临界锅炉性能在线预测方法[J]. 中国电机工程学报,2015,35(10):2487-2494.
TONG Ying,ZHONG Wei,TONG Shuiguang. Performance on-line prediction of supercritical boilers based on mechanism and data-driven model[J]. Proceedings of the CSEE,2015,35(10):2487-2494.

[2] 黄天恩,郭庆来,孙宏斌,等. 模型-数据混合驱动的电网安全特征选择和知识发现关键技术与工程应用[J]. 电力系统自动化,2019,43(1):95-104,208.
HUANG Tianen,GUO Qinglai,SUN Hongbin,et al. Hybrid model and data driven concepts for power system security feature selection and knowledge discovery:key technologies and engineering application[J]. Automation of Electric Power Systems,2019,43(1):95-104,208.

[3] 张平,潘学萍,薛文超. 基于小波分解模糊灰色聚类和 BP 神经网络的短期负荷预测[J]. 电力自动化设备,2012,32(11):121-125,141.
ZHANG Ping,PAN Xueping,XUE Wenchao. Short-term load forecasting based on wavelet decomposition,fuzzy gray corre-

lation clustering and BP neural network[J]. Electric Power Automation Equipment,2012,32(11):121-125,141.

[4] 高亚静,刘栋,程华新,等. 基于数据驱动的短期风电出力预估-校正预测模型[J]. 中国电机工程学报,2015,35(11):2645-2653.
GAO Yajing,LIU Dong,CHENG Huaxin,et al. Predictor-corrector model of wind power forecast based on data-driven[J]. Proceedings of the CSEE,2015,35(11):2645-2653.

[5] 石鑫,朱永利,宁晓光,等. 基于深度自编码网络的电力变压器故障诊断[J]. 电力自动化设备,2016,36(5):122-126.
SHI Xin,ZHU Yongli,NING Xiaoguang,et al. Transformer fault diagnosis based on deep auto-encoder network[J]. Electric Power Automation Equipment,2016,36(5):122-126.

[6] 林君豪,张焰,赵腾,等. 基于改进卷积神经网络拓扑特征挖掘的配电网结构坚强性评估方法[J]. 中国电机工程学报,2019,39(1):84-96,323.
LIN Junhao,ZHANG Yan,ZHAO Teng,et al. Structure strength assessment method of distribution network based on improved convolution neural network and network topology feature mining [J]. Proceedings of the CSEE,2019,39(1):84-96,323.

[7] 孙国强,钱婧,陈亮,等. 基于深度信念网络伪量测建模的配电网状态估计[J]. 电力自动化设备,2018,38(12):94-99.
SUN Guoqiang,QIAN Qiang,CHEN Liang,et al. State estimation of distribution system based on pseudo measurement modeling using deep belief network[J]. Electric Power Automation Equipment,2018,38(12):94-99.

[8] 李彬,彭曙蓉,彭君哲,等. 基于深度学习分位数回归模型的风电功率概率密度预测[J]. 电力自动化设备,2018,38(9):15-20.
LI Bin,PENG Shurong,PENG Junzhe,et al. Wind power probability density forecasting based on deep learning quantile regression model[J]. Electric Power Automation Equipment,2018,38(9):15-20.

[9] 彭宇文,刘克文. 基于改进核心向量机的配电网理论线损计算方法[J]. 中国电机工程学报,2011,31(34):120-126.
PENG Yuwen,LIU Kewen. A distribution network theoretical line loss calculation method based on improved core vector machine[J]. Proceedings of the CSEE,2011,31(34):120-126.

[10] 邹云峰,梅飞,李悦,等. 基于数据挖掘技术的台区合理线损预测模型研究[J]. 电力需求侧管理,2015,17(4):25-29.
ZOU Yunfeng,MEI Fei,LI Yue,et al. Prediction model research of reasonable line loss for transformer district based on data mining technology[J]. Power Demand Side Management,2015,17(4):25-29.

[11] 欧阳欣,吴裕生. 基于 FCM 聚类和 BP 神经网络的配电网线损计算方法[J]. 电气应用,2017,36(16):44-49.

[12] 文福拴,韩祯祥. 基于分群算法和人工神经网络的配电网线损计算[J]. 中国电机工程学报,1993,13(3):43-53.
WEN Fushuan,HAN Zhenxiang. The calculation of energy losses in distribution systems based upon a clustering algorithm and an artificial neural network model[J]. Proceedings of the CSEE,1993,13(3):43-53.

[13] 文福拴,韩祯祥. 联合采用 KOHONEN 模型和 BP 模型的配电网线损计算[J]. 电工技术学报,1993,8(3):16-20.
WEN Fushuan,HAN Zhenxiang. The calculation of energy losses in distribution systems based upon KOHONEN's model and BP model[J]. Transactions of China Electrotechnical Society,1993,8(3):16-20.

[14] 何维民,邹云峰,梅飞,等. 结合主元分析与神经网络的台区合理线损预测[J]. 电器与能效管理技术,2015(20):61-65.
HE Weimin,ZOU Yunfeng,MEI Fei,et al. Prediction method of reasonable line loss for transformer district combining PCA and ANN[J]. Electrical & Energy Management Techno-

- logy, 2015(20):61-65.
- [15] 张义涛,王泽忠,刘丽平,等. 基于灰色关联分析和改进神经网络的10 kV配电网线损预测[J]. 电网技术, 2019, 43(4): 1404-1410.
ZHANG Yitao, WANG Zezhong, LIU Liping, et al. A 10 kV distribution network line loss prediction method based on grey correlation analysis and improved artificial neural network[J]. Power System Technology, 2019, 43(4):1404-1410.
- [16] 李亚,刘丽平,李柏青,等. 基于改进K-Means聚类和BP神经网络的台区线损率计算方法[J]. 中国电机工程学报, 2016, 36(17):4543-4552.
LI Ya, LIU Liping, LI Baiqing, et al. Calculation of line loss rate in transformer district based on improved K-Means clustering algorithm and BP neural network[J]. Proceedings of the CSEE, 2016, 36(17):4543-4552.
- [17] 辛开远,杨玉华,陈富. 计算配电网线损的GA与BP结合的新方法[J]. 中国电机工程学报, 2002, 22(2):79-82.
XIN Kaiyuan, YANG Yuhua, CHEN Fu. An advanced algorithm based on combination of GA with BP to energy loss of distribution system[J]. Proceedings of the CSEE, 2002, 22(2): 79-82.
- [18] 李秀卿,赵丽娜,孟庆然,等. IGA优化的神经网络计算配电网理论线损[J]. 电力系统及其自动化学报, 2009, 21(5):87-91.
LI Xiuqing, ZHAO Lina, MENG Qingran, et al. Calculation of line losses in distribution systems using artificial neural network aided by immune genetic algorithm[J]. Proceedings of the CSU-EPSA, 2009, 21(5):87-91.
- [19] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7):1527-1554.
- [20] SCHMIDHUBER J. Deep learning in neural networks:an overview[J]. Neural Networks, 2015, 61:85-117.
- [21] HINTON G, SALAKHUTDINOV R. Discovering binary codes for documents by learning deep generative models[J]. Topics in Cognitive Science, 2011, 3(1):74-91.
- [22] BALLAN L, BAZZICA A, BERTINI M, et al. Deep networks for audio event classification in soccer videos[C]//2009 IEEE International Conference on Multimedia and Expo. New York, USA:IEEE, 2009:474-477.
- [23] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition:the shared views of four research groups[J]. IEEE Signal Processing Magazine, 2012, 29(6):82-97.
- [24] TORRALBA A, FERGUS R, WEISS Y. Small codes and large image databases for recognition[C]//2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, USA:IEEE, 2008:1-8.
- [25] CHEN Erkang, YANG Xiaokang, ZHA Hongyuan, et al. Learning object classes from image thumbnails through deep neural networks[C]//Proceeding of 2008 International Conference on Acoustics Speech and Signal Processine. Las Vegas, USA:IEEE, 2008:829-832.

作者简介:



马丽叶

马丽叶(1980—),女,河北秦皇岛人,副教授,博士,主要研究方向为电力系统经济运行分析与控制(**E-mail**: maliye@ysu.edu.cn);

刘建恒(1993—),男,河北石家庄人,硕士研究生,主要研究方向为电力系统经济运行分析与控制(**E-mail**:461985501@qq.com);

卢志刚(1963—),男,河北秦皇岛人,教授,博士,主要研究方向为电力系统经济运行分析与控制(**E-mail**:zhglu@ysu.edu.cn)。

(编辑 王锦秀)

Theoretical line loss calculation method of low voltage transform district based on deep belief network

MA Liye¹, LIU Jianheng¹, LU Zhigang¹, WANG Haiyun², YUAN Qingfang², YANG Liping²

(1. Key Laboratory of Power Electronics for Energy Conservation and Motor Drive of Hebei Province, Yanshan University, Qinhuangdao 066004, China;

2. Electric Power Research Institute of State Grid Beijing Electric Power Company, Beijing 100075, China)

Abstract: Aiming at the problem that the theoretical line loss calculation of low voltage transform district is difficult brought by complex distribution of lines and huge number of terminals, a novel calculation method of theoretical line loss based on DBN (Deep Belief Network) is proposed for low voltage transform district. In the training process, the greedy algorithm is used to carry out unsupervised layer-by-layer pre-training of the neural network layer in DBN model first, and then supervised global fine-tuning training of the model is implemented. Adam (Adaptive moment estimation) optimizer is adopted to improve the calculation accuracy. The measured 2 140 data of the transform district in a certain area are taken as the samples for simulation and calculation, and results show that the DBN line loss calculation model has better generalization ability, accuracy and rapidity compared with the shallow neural network, and Adam optimizer is superior to RMSProp (Root Mean Square Prop) and SGD (Stochastic Gradient Descent) in line loss calculation.

Key words: low voltage transform district; theoretical line loss; DBN; greedy layer training algorithm; Adam